

# Prediksi Indeks Gangguan Geomagnet Lokal K Menggunakan Jaringan Fungsi Basis Radial (JFBR)

Anisa\*

## Abstrak

Aktivitas geomagnet merupakan salah satu faktor penting dalam pemodelan sistem input-output parameter ionosfer, karena aktivitas ini memegang peranan yang besar dalam variabilitas ionosfer. Aktivitas geomagnet lokal direpresentasikan dengan indeks gangguan geomagnet K. Untuk mendapatkan prediksi aktivitas geomagnet yang akurat perlu dibuat model nonlinier indeks aktivitas geomagnet. Salah satu model yang telah digunakan secara luas dalam prediksi nonlinier adalah model jaringan (syaraf tiruan) fungsi basis radial (JFBR). Dalam makalah ini, digunakan data harian indeks gangguan geomagnet lokal K mulai dari tahun 1997-2003 untuk prediksi jangka pendek aktivitas geomagnet satu tahap ke depan, yang diperoleh dari Stasiun Pengamat Geofisika (SPG) Tangerang.

**Kata-kata kunci:** *gangguan geomagnet, prediksi, jaringan fungsi basis radial.*

## 1 Pendahuluan

Dalam bidang komunikasi radio menggunakan HF (*High Frequency*) sebagai frekuensi gelombang pembawa, lapisan ionosfer merupakan media pemantul gelombang untuk komunikasi dari titik ke titik. Ionosfer adalah lapisan di atmosfer atas yang terdiri dari partikel-partikel bermuatan pada ketinggian sekitar 60 sampai 1000 km [11], yang dapat mempengaruhi perambatan gelombang radio.

Namun kondisi media pemantul ini tidak selalu stabil karena dipengaruhi oleh beberapa hal, seperti gangguan aktivitas matahari, variasi medan magnet bumi, lokasi dan waktu setempat yang dapat mempengaruhi komunikasi radio. Jika ionosfer terganggu atau mengalami ketidak stabilan akan dapat menyebabkan *fading* pada sinyal gelombang radio yang dipantulkan atau melewati ionosfer. Untuk itu prediksi frekuensi kritis lapisan ionosfer dengan tingkat akurasi yang tinggi pada waktu yang akan datang perlu dilakukan, sehingga deteksi dini karakteristik lapisan tersebut yang dapat mempengaruhi pelayanan komunikasi radio jarak jauh dapat dilakukan lebih awal.

Model ionosfer yang dibuat biasanya menggunakan beberapa parameter sebagai input model. Jika parameter input tersebut dapat diprediksi dengan tingkat akurasi yang tinggi untuk prediksi beberapa hari yang akan datang, maka hasil prediksi tersebut dapat digunakan sebagai input dalam model ionosfer. Parameter-parameter input ionosfer yang biasa digunakan sebagai indeks gangguan geomagnet diantaranya adalah indeks gangguan geomagnet lokal K, yang merupakan data pengamatan lokal Indonesia. Salah satu stasiun yang mengamati indeks gangguan geomagnet lokal tersebut adalah Stasiun Pengamat Geofisika (SPG) Tangerang..

Muslim [9] dalam penelitiannya dengan menggunakan model linier Vektor Autoregression (VAR) dan model Autoregression (AR) mendapatkan tingkat akurasi yang relatif kecil untuk prediksi indeks gangguan geomagnet global  $A_p$ , dengan simpangan atau tingkat kesalahan yang sama untuk kedua model, masing-masing sebesar 59%. Untuk itu, penelitian dalam makalah ini di fokuskan pada penggunaan model non linier untuk prediksi aktivitas gangguan geomagnet lokal K tersebut.

---

\* Staf Pengajar pada Jurusan Matematika FMIPA Universitas Hasanuddin Makassar

Model Jaringan (syaraf tiruan) Fungsi Basis Radial, selanjutnya disebut JFBR, adalah salah satu model nonlinier jangka pendek yang digunakan untuk prediksi aktivitas gangguan geomagnet beberapa hari yang akan datang [5]. Dalam makalah ini penulis menggunakan data deret waktu indeks gangguan geomagnet lokal K untuk pembuatan model dan melihat tingkat akurasi dari model tersebut. Dengan data indeks aktivitas gangguan geomagnet harian dapat dibuat model JFBR untuk prediksi satu tahap ke depan secara iterasi.

## 2 Pemodelan Jaringan Fungsi Basis Radial (JFBR)

Model umum untuk Jaringan Fungsi Basis Radial (JFBR) diuraikan berikut ini. Jika terdapat  $N$  pasang data input-output,  $\{\mathbf{x}_i, y_i\}_{i=1}^N$ , maka secara umum model JFBR dituliskan dalam persamaan berikut :

$$y(\mathbf{x}) = f(\mathbf{x}) + e(\mathbf{x}) = \hat{y}(\mathbf{x}) + e(\mathbf{x}) = \sum_{j=1}^K \omega_j \phi_j(\mathbf{x}) + e(\mathbf{x}), K \leq M. \quad (1)$$

dimana  $\mathbf{x}$  adalah peubah input berdimensi- $p$ ,  $\mathbf{x}' = (x_1, x_2, \dots, x_p)$ ,  $\omega_j$  adalah bobot dari parameter yang akan ditentukan nilainya (identik dengan pendugaan koefisien regresi pada model statistika konvensional),  $K$  adalah optimum banyaknya bobot yang diperoleh dalam pembelajaran model sehingga simpangan dengan data pembelajaran yang lain lebih kecil dari  $\xi$ ,  $0 < \xi < 1$ .  $\phi(\bullet)$  adalah fungsi Basis Radial, suatu fungsi nonlinear yang merupakan fungsi transfer atau fungsi aktivasi dalam model JFBR, dalam hal ini  $\phi_j(\mathbf{x})$  merupakan fungsi dari  $\|\mathbf{x} - \mathbf{c}_j\|$ , fungsi dari jarak Euclid antara vektor input  $\mathbf{x}$  dengan pusat-pusat dari fungsi basis yang dinotasikan dengan  $\mathbf{c}_j$ ,  $\mathbf{c}_j$  merupakan vektor rata-rata (sentroid) dari  $j$  amatan pertama dari vektor input dalam pembelajaran model.  $M$  menyatakan banyaknya data yang disediakan dalam pembelajaran model,  $M < N$ , sedangkan  $e(\mathbf{x})$  menyatakan galat pemodelan pada  $\mathbf{x}$  [1].

Pada penelitian ini, model JFBR akan digunakan untuk mencari nilai dugaan satu hari ke depan untuk indeks gangguan geomagnet lokal K. Pada tahap ini model JFBR akan digunakan pada data amatan yang berasal dari satu sumber tetap, yang terjadinya berdasarkan indeks waktu  $t$  secara berurutan dengan interval waktu yang tetap. Data seperti ini disebut juga sebagai data runtun waktu atau *time series* [4]. Jika setiap pengamatan pada suatu peubah input tertentu dinyatakan dalam  $x_1, x_2, \dots, x_{t-2}, x_{t-1}, x_t$ , dimana  $t$  adalah waktu pengamatan terakhir atau yang terbaru, maka secara umum model JFBR untuk peubah input tersebut dituliskan dalam persamaan berikut :

$$x_{t+1}(\mathbf{x}_t) = x_{t+1}(x_1, x_2, \dots, x_{t-1}, x_t) = f(\mathbf{x}_t) + e_{t+1} = \sum_{j=1}^K \omega_j \phi_j(\mathbf{x}_t) + e_{t+1} \quad (2)$$

dengan proses perhitungan seperti pada persamaan (1).

Pada penelitian Muslim [9] dengan model VAR (*Vector Autoregression*), diperoleh bahwa VAR orde 3 atau VAR(3), merupakan model terbaik berdasarkan kriteria pemilihan model AIC (*Akaike's Information Criterion*). Berdasarkan hal tersebut, maka dalam penelitian ini model yang digunakan untuk mendapatkan nilai dugaan satu hari ke depan atau  $x_{t+1}$ , adalah berdasarkan penggunaan tiga pengamatan sebelumnya, yang dituliskan dalam model berikut :

$$x_{t+1}(\mathbf{x}_t) = x_{t+1}(x_{t-2}, x_{t-1}, x_t) = f(x_{t-2}, x_{t-1}, x_t) + e_{t+1} = \sum_{j=1}^K \omega_j \phi_j(\mathbf{x}_t) + e_{t+1} \quad (3)$$

Beberapa fungsi aktivasi yang bisa digunakan untuk JFBR, di antaranya<sup>2</sup> :

<sup>2</sup> <http://www.anc.ed.ac.uk/mjo/intro/node33.html> [Januari 2003]

- a. Fungsi aktivasi Gauss, dengan persamaan  $\phi(z) = e^{-\frac{1}{\beta}z^2}$ , dimana konstanta  $\beta$  yang dikenal dengan *spread* [7] merupakan lebar dari fungsi Gauss tersebut
  - b. Fungsi aktivasi Multikuadratik, dengan persamaan  $\phi(z) = (1+z)^{1/2}$
  - c. Fungsi aktivasi Invers Multikuadratik, dengan persamaan  $\phi(z) = (1+z)^{-1/2}$
  - d. Fungsi aktivasi Cauchy dengan persamaan  $\phi(z) = (1+z)^{-1}$  dan
  - e. Fungsi aktivasi Logistik, dengan persamaan  $\phi(z) = (1+e^{-z})^{-1}$
- dimana  $z$  adalah fungsi dari  $\|\mathbf{x} - \mathbf{c}_j\|$ , sebagaimana yang telah dijelaskan di atas.

Hutchinson [1] dalam penelitiannya menggunakan data harian tahun 1989 – 1991 indeks harga permintaan pasar untuk sektor industri negara Jepang, dan Schumacher *et al.* [1] dalam penelitiannya menggunakan data di bidang kesehatan, menyatakan bahwa fungsi aktivasi Gauss lebih *smooth* jika dibandingkan dengan fungsi Logistik. Sedangkan berdasarkan pada keragaman yang dimiliki oleh fungsi-fungsi tersebut, fungsi aktivasi Gauss mempunyai ragam yang lebih kecil jika dibandingkan dengan fungsi Cauchy, Multikuadratik dan juga Invers Multikuadratik, sehingga penelitian ini akan difokuskan pada penggunaan fungsi aktivasi Gauss.

Bentuk fungsi  $\phi(\bullet)$  untuk JFBR jika fungsi aktivasi Gauss yang digunakan adalah :

$$\phi_j(\mathbf{x}) = \exp \left[ -\frac{1}{\beta} (\|\mathbf{x} - \mathbf{c}_j\|)^2 \right] \quad (4)$$

Terdapat beberapa algoritma yang bisa digunakan untuk menentukan pembobot-pembobot yang optimal sedemikian hingga menghasilkan galat (*error*) yang minimum, di antaranya adalah algoritma *Orthogonal Least Squares* (OLS), *Levenberg-Marquardt* (LM) dan *Quasi-Newton* (QN). Chng *et al.* [1] menyatakan bahwa OLS adalah suatu algoritma yang efisien digunakan pada seleksi alur maju (*forward selection*), sedangkan Chen *et al.* [3] menyatakan bahwa OLS adalah algoritma yang sederhana dan efisien untuk prediksi data runtun waktu non linear dengan menggunakan JFBR, sehingga penelitian ini akan difokuskan pada penggunaan algoritma pembelajaran OLS.

Fungsi galat yang akan digunakan dalam penelitian ini adalah simpangan mutlak (*Mean Absolut Deviation* atau MAD), dengan pertimbangan bahwa fungsi galat tersebut yang lebih banyak digunakan dalam bidang ionosfer dan geofisika pada umumnya, dan relatif lebih mudah dalam proses perhitungannya. Hal lain yang mendasari pemilihan fungsi galat ini adalah pertimbangan bahwa fungsi galat MAD efektif digunakan dalam penghalusan dan pemulusan model [1]. Fungsi galat dalam MAD ditunjukkan pada persamaan berikut

$$MAD = \frac{1}{N-M} \sum_{j=1}^{N-M} |y_j - \hat{y}_j| \quad (5)$$

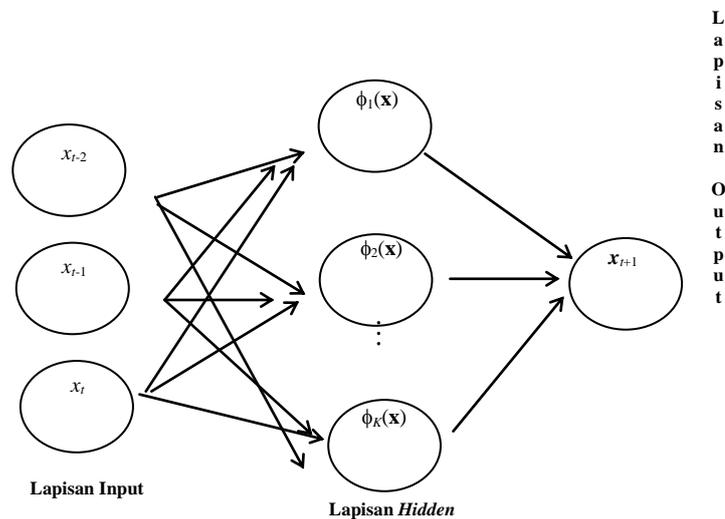
dimana  $M$  adalah banyaknya data yang digunakan dalam pembelajaran, sedangkan  $y_j$  dan  $\hat{y}_j$  masing-masing peubah target dan output yang diperoleh dari proses pembelajaran dan pengujian model dengan menggunakan JFBR. Model JFBR yang dipilih adalah model yang memiliki nilai MAD yang terkecil.

### 3 Data dan Metode

Data yang digunakan dalam penelitian ini adalah data sekunder yang merupakan data total amatan harian pengamatan indeks gangguan geomagnet lokal K tahun 1997 - 2003,

yang diamati setiap hari dari jam 00.00 LT sampai 23.00 LT, dengan interval waktu 3 jam. Analisis data menggunakan program Matlab 6.5.

Berdasarkan pada persamaan (1), (3), dan (4), maka struktur dasar JFBR untuk prediksi indeks gangguan geomagnet lokal K diperlihatkan pada diagram berikut.



**Gambar 1.** Struktur dasar model Jaringan Fungsi Basis Radial.

Berikut arti dari notasi yang digunakan pada gambar di atas :

$\phi_1(\mathbf{x}), \phi_2(\mathbf{x}), \dots, \phi_K(\mathbf{x})$  = Berturut-turut adalah fungsi transfer atau fungsi aktivasi pertama, kedua dan ke- $K$ , dimana  $K$  adalah optimum banyaknya bobot yang diperoleh dalam pembelajaran. Dalam hal ini, fungsi aktivasi yang digunakan adalah fungsi Gauss, maka  $\phi_j(\mathbf{x}) = \exp[-\frac{1}{\beta} (\|\mathbf{x} - \mathbf{c}_j\|)^2]$ ,  $j = 1, 2, \dots, K$ ,  $K \leq M$ , dimana  $M$  banyaknya data yang disediakan untuk pembelajaran model.

$x_{t-2}, x_{t-1}, x_t, x_{t+1}$  = Berturut-turut adalah data amatan suatu peubah input tertentu, misalkan peubah  $x_i$  yang dideskripsikan pada Tabel 1,  $i = 1, 2, 3^a, 3^b, 3^c$ , dimana nilai dugaan  $x_{t+1}$  diperoleh berdasarkan penggunaan tiga amatan sebelumnya, yaitu  $x_{t-2}, x_{t-1}$ , dan  $x_t$ .

Berbagai ukuran data dalam pembelajaran model, dan berbagai lebar *spread*  $\beta$  pada suatu interval tertentu untuk fungsi aktivasi Gauss yang digunakan dalam penelitian ini diberikan pada tabel berikut. Untuk mempercepat proses pembelajaran dan pengujian model, nilai  $\beta$  pada interval yang digunakan pada ukuran *spread* kecil, sedang dan lebar berturut-turut adalah nilai  $\beta$  dengan kelipatan 10, 100 dan 1000.

**Tabel 1** Berbagai ukuran data dan lebar *spread* yang digunakan dalam pembelajaran model JFBR

Ukuran Data		Ukuran <i>Spread</i>	
Kecil	$M = 20\%$ data	Kecil	$0 < \beta \leq 500$
Sedang	$M = 50\%$ data	Sedang	$500 < \beta \leq 5,000$
Besar	$M = 80\%$ data	Lebar	$5,000 < \beta \leq 50,000$

## 4 Hasil dan Pembahasan

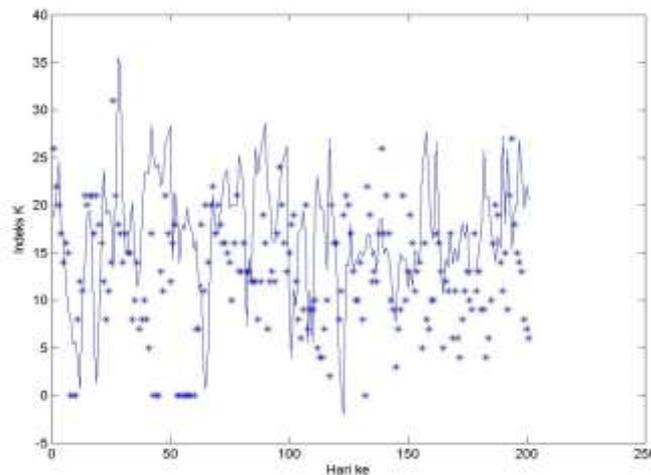
Berdasarkan pembelajaran dan pengujian model JFBR pada data indeks gangguan geomagnet lokal K, diperoleh nilai MAD yang diberikan pada Tabel 2 berikut.

**Tabel 2** Nilai MAD berdasarkan pembelajaran dan pengujian model JFBR

Indeks Gangguan Geomagnet Lokal K	Kecil, $M = 20\%$ data	$0 < \beta \leq 500$	14.641
		$500 < \beta \leq 5,000$	7.225
		$5,000 < \beta \leq 50,000$	7.225
	Sedang, $M = 50\%$ data	$0 < \beta \leq 500$	20.791
		$500 < \beta \leq 5,000$	5.095
		$5,000 < \beta \leq 50,000$	5.004
	Besar, $M = 80\%$ data	$0 < \beta \leq 500$	20.989
		$500 < \beta \leq 5,000$	4.104
		$5,000 < \beta \leq 50,000$	<b>3.912</b>

Dari Tabel 2 di atas terlihat bahwa kombinasi antara ukuran data besar dan *spread* yang lebar pada data ini, umumnya memberikan tingkat akurasi yang lebih baik pada pembelajaran dan pengujian model ini jika dibandingkan kombinasi ukuran data dan *spread* lainnya. Dari Tabel 2 dapat dilihat bahwa tingkat akurasi maksimum dengan nilai simpangan terkecil untuk model prediksi indeks gangguan geomagnet lokal K ini, terjadi pada penggunaan 80% dari jumlah seluruh data dalam pembelajaran model dengan lebar *spread*  $5,000 < \beta \leq 50,000$ , dengan nilai MAD sebesar 3.912%. Sedangkan nilai simpangan yang besar terjadi pada penggunaan kombinasi ukuran data kecil, yaitu 20% dari jumlah seluruh data dengan berbagai lebar *spread* yang digunakan, maupun ukuran data sedang atau besar dalam pembelajaran dengan lebar *spread* kecil ( $0 < \beta \leq 500$ ). Hal ini didukung pula oleh hasil penelitian sebelumnya pada indeks aktivitas matahari bilangan sunspot R untuk data tahun 1998 – 2002, dimana diperoleh hasil bahwa ukuran data dan *spread* yang digunakan dalam pembelajaran model mempengaruhi tingkat akurasi yang diperoleh [2]. Semakin besar ukuran data dan *spread* yang digunakan maka tingkat akurasi prediksi model harian yang diperoleh juga semakin tinggi, ditandai dengan nilai simpangan yang semakin kecil.

Selain berdasarkan pada nilai MAD, hal ini juga bisa dilihat pada plot pembelajaran dan pengujian model yang diberikan pada gambar berikut..



**Gambar 2.** Plot data dan prediksi aktivitas gangguan geomagnet, untuk ukuran data besar dan *spread* lebar

Pada Gambar 2 terlihat bahwa plot prediksi (garis \_\_\_\_\_) mendekati plot data yang sebenarnya (dalam tanda \*).

## 5 Kesimpulan dan Saran

Dari pembahasan hasil prediksi JFBR dapat disimpulkan bahwa indeks gangguan geomagnet lokal K memberikan hasil yang dengan tingkat akurasi yang lebih baik pada penggunaan ukuran data yang besar dan *spread* yang lebar dalam pembelajaran dan pengujian model.

Penelitian lanjut yang bisa dilakukan antara lain verifikasi model JFBR dengan prediksi jangka pendek indeks gangguan geomagnet lokal K beberapa tahap ke depan dan membandingkan hasilnya dengan hasil prediksi yang telah dilakukan oleh NOAA untuk beberapa hari yang akan datang, sehingga deteksi dini aktivitas gangguan geomagnet yang dapat mempengaruhi komunikasi radio jarak jauh dapat dilakukan lebih awal.

### Daftar Pustaka

- [1] Anisa, 2005, "Penggunaan Jaringan fungsi basis radial pada pemodelan ionosfer di atas Sumedang", Tesis, Institut Pertanian Bogor.
- [2] Anisa and Muslim, B., 2004, "Prediksi aktivitas matahari jangka pendek menggunakan jaringan fungsi basis radial", Prosiding Pertemuan Ilmiah Nasional Basic Science I, FMIPA Unibraw Malang, 2004.
- [3] Chen, S., Cowan, C.F.N., and Grant, P.M., 1991, "Orthogonal least squares learning algorithm for radial basis function networks", IEEE Transaction on Neural Networks. 2,302-309.
- [4] Cryer, J.D., 1986, "Time Series Analysis", PWS-KENT Publishing Company, Boston.
- [5] Francis, N.M., Brown, A.G., Cannon, P.S., & Broomhead, D.S., 2000, "Nonlinear prediction of the hourly foF2 time series in conjunction with the interpolation of missing data points", Physica Chemistry Earth. 25, 261-265.
- [6] Habirun, "Model variasi komponen H medan magnet bumi menggunakan analisis deret Fourier", Jurnal STATISTIKA, Forum Teori dan Aplikasi. Edisi Khusus, 3 (2003), 77-83.

- [7] Howlett, R.J., and Jain, L.C., 2001, "Radial Basis Function Networks 1", Physica-Verlag, A Springer-Verlag Company.
- [8] Howlett, R.J., and Jain, L.C., 2001, "Radial Basis Function Networks 2", Physica-Verlag, A Springer-Verlag Company.
- [9] Muslim, B., 2002 "Prediksi parameter input model ionosfer menggunakan vector auto autoregression", Makalah Laporan Riset Unggulan Kemandirian Kedirgantaraan (RUUK) LAPAN Bandung, Tahun 2002. LAPAN Bandung.
- [10] Ripley, B.D., 1996, "Pattern Recognition and Neural Networks", Cambridge University Press, London.
- [11] Schun, R.W. and Nagy, A.F., 2000, "Ionospheres : Physics, Plasma Physics, and Chemistry", Cambridge University Press, London.
- [12] Stening, R.J., 1992, "Modelling the low latitude F region", Journal Atmospheric Terr. Physica. 54, No. 11/12.